

# Mesterséges neurális hálózatok motorteknikai alkalmazása

## Application of artificial neural networks for internal combustion engines

VIRT Márton<sup>1</sup>, Dr. ZÖLDY Máté<sup>1</sup>

1 – Budapesti Műszaki és Gazdaságtudományi Egyetem, 1111 Budapest, Műegyetem rkp. 3.,  
tel.: +36 1 463-1111, fax: +36 1 463-1110, [info@bme.hu](mailto:info@bme.hu), [www.bme.hu](http://www.bme.hu)

### Abstract

Nowadays, artificial neural networks (ANNs) are widely used in the industry due to their various advantageous properties. The state-of-art researches are examining whether the technology can be used effectively in the control of internal combustion engines and in other engine-relevant applications. This paper analyses the predictive power of multilayer perceptron (MLP) neural networks in internal combustion engine applications. The training dataset of the used MLP network is derived from a stationary measurement dataset of a commercial diesel engine operated with conventional diesel fuel. Adam algorithm was used to train the neural network, and the correct network architecture was determined with a grid-search algorithm. The presented neural network was able to make accurate predictions. Thus, the results of our work show, in accordance with the literature, that MLP networks can accurately predict the investigated engine parameters at different stationary operating conditions.

**Keywords:** Artificial intelligence, MLP network, diesel engine, combustion, prediction

### Kivonat

Manapság a mesterséges neurális hálózatokat (ANN) különböző előnyös tulajdonságaik miatt az ipar számos területén alkalmazzák. Az új kutatások vizsgálják, hogy a belsőégésű motorok szabályázatechnikájában, illetve egyéb vonatkozó területeken hatékonyan alkalmazható-e a technológia. Ez a dolgozat a többrétegű perceptronos (MLP) neurális hálózatok predikációs képességét elemzi motorteknikai alkalmazás esetén. Az elkészített MLP hálózat tanító adatsora egy haszonjármű dízelmotor stacioner mérési adatsorából származik hagyományos dízel üzemanyag alkalmazásával. A hálózat betanításához Adam algoritmust használtunk, a helyes hálóstruktúrát pedig grid-search eljárással állapítottuk meg. Az elkészített neurális hálózat képes volt pontos predikciók készítésére. A dolgozat eredményei így a szakirodalommal összhangban azt mutatják, hogy az MLP hálózatok alkalmasak lehetnek az általunk vizsgált motorikus paraméterek pontos előrejelzésére a motor különböző stacioner üzemiállapotaiban.


**Kulcsszavak:** Mesterséges intelligencia, MLP hálózat, dízelmotor, égésfolyamat, predikció

## 1. BEVEZETÉS

A szigorodó emissziós előírások a járműipart az egyre környezetkímélőbb technológiák kifejlesztésére ösztönzik. A belsőégésű motorok az új hajtástechnikák megjelenése ellenére rövid és középtávon még mindig a közlekedés egyik legmeghatározóbb szereplői lesznek, így indokolt a technológia további intenzív fejlesztése [1]. A motorok egyre bonyolultabbá válnak és egyre több az elektronikus beavatkozási lehetőség ezek működésébe [2]. Ezeknek a komplex rendszereknek a szabályzásához a hagyományos térkép alapú motorvezérlők már nem nyújtanak igazán hatékony megoldást. Egy modern motor akár 30 szenzor alapján is dolgozhat, és ez a szám a jövőben tovább nőhet így várhatóan a motorok kalibrációja egyre költségesebbé, a szükséges térképek pedig túl nagyméretűvé válnak. A modell alapú vezérlők ezért hatékonyabb megoldást adhatnak a problémára. A pontos fizikai modellek megalkotása nehéz feladat, futtatásukhoz pedig gyakran nagy számítási kapacitásra van szükség, ezért ezek kiváltásának lehetőségét vizsgálni kell.

A mesterséges neurális hálózat (ANN) alapú modell prediktív vezérlők megoldást nyújthatnak a problémára. A neurális hálózatokkal black-box módon kezelhető modelleket nyerhetünk, melyek

megalkotásához nem szükséges a fizikai és kémiai folyamatok ismerete. A modell pusztán egy a folyamat szempontjából reprezentatívnak vehető tanító adatsor bemenetei és kimenetei közti matematikai leképezéssel áll elő. A betanított neurális hálózatok kis számítási igényrel képesek pontos predikciót adni a különböző bemeneti paraméterek alapján. Az ANN egy olyan mesterséges intelligencia (AI) algoritmus, ami a biológiai idegrendszer mintájára készült. Itt a neuronok bemenetei a dendritek, melyen keresztül az idegsejt elektromos impulzusokat kap. Ha ezeknek az impulzusoknak az összege eléri egy határértéket, akkor az idegsejt az axonján keresztül kisül a többi idegsejt felé [3]. A kortárs kutatásokban leggyakrabban többrétegű perceptronos (MLP) hálózatokat használnak. Egy neuron matematikailag egy súlyozott összegzőnek tekinthető, mely a különböző súllyal figyelembe vett kapcsolatokon beérkező bemeneti jeleket összegzi. A neuron végleges kimenete, vagyis az aktivációja egy aktivációs függvény segítségével áll elő. A neuronok rétegekbe rendeződnek, és a szomszédos rétegek összes neuronja kapcsolatban áll egymással. A bemenetek és a kimeneti réteg között találhatóak a rejtett rétegek. Ha legalább egy rejtett réteggel rendelkezik a hálózat, akkor az egy univerzális approximátor, így bármilyen függvény tetszőleges pontossággal közelíthető vele. A tanítás hibavisszaterjesztéses eljárással (BP) történik, ami egy olyan iteratív módszer mely során a kapcsolatok súlyai úgy módosulnak, hogy a tanító adatsor bemeneteiből a kívánt pontossággal előáll a kimenet. Az MLP hálózatok struktúráját az 1. ábra szemlélteti.



1. ábra. Az MLP hálózatok architektúrája [4]

Az irodalomban több cikk is foglalkozik a neurális hálózatok predikciós képességével motorteknikai alkalmazások esetén. A különböző motorikus jellemzők, mint például a teljesítmény [5], vagy az effektív fajlagos fogyasztás és a kipufogógáz hőmérséklet [6] mellett az emissziók is pontosan becsülhetők [7]. A hálózat rendelkezhet kevés bemeneti paraméterrel, melyek egyszerű módon írják le a motor üzemállapotát [8], de akár több belső állapot is megadható a pontosabb eredmények érdekében, mint például a különböző hőmérsékletek és nyomások, valamint a befecskendezőrendszer paraméterei [4]. ANN-ek segítségével a tüzelőanyag keverékek hatása is pontosan modellezhető [9]. Ilyenkor leggyakrabban egy komponens keverési aránya jellemzi a tüzelőanyagot a bemenetek között [10], de akár a különböző tüzelőanyag tulajdonságok is megadhatók, például a cetánszám vagy a sűrűség [11].

Jelen vizsgálat célja, hogy egy haszonjármű dízelmotor különböző üzemállapotaiban megvizsgáljuk az MLP hálózatok predikciós képességét különböző EGR ráták alkalmazása mellett. Összesen 4 motorikus paramétert vizsgáltunk meg: az indikált középnyomást (IMEP), az égési csúcshőmérsékletet ( $T_{max}$ ), az égéstartamot (DoC), és a motornyomatékot (M). Ehhez 4 külön MLP hálózatot tanítunk be, mindegyik háló 2 bemeneti paraméterrel rendelkezik, melyek a fordulatszám és az EGR ráta.

## 2. AZ ALKALMAZOTT ESZKÖZÖK ÉS MÓDSZEREK

### 1.1. A mérőrendszer

A motorfékpadai méréseket egy 3922 cm<sup>3</sup>-es, 125 kW névleges effektív teljesítményű és 17,3-mas kompresszióviszonyú Cummins ISBe 170 30 típusú négyhengeres, négyütemű, közös nyomócsöves haszonjármű dízelmotoron végeztük el ásványi dízelolaj használatával. A motor magas (HP) és alacsony nyomású (LP) kipufogógáz visszavezető rendszerrel (EGR), turbófeltöltővel és intercoolerrel szerelt. A motort egy örvényáramú fékgép fékezi. A hengernyomást egy AVL GH13P típusú piezoelektromos nyomásérzékelő mérte, így indikálással meghatározható a látszólagos égésfüggvény, valamint az ideális gázok állapotegyenlete segítségével a hengerhőmérséklet. Az égésfolyamat analízishez egy AVL 612 Indi-Smart berendezést használtunk, a főtengely pozíciót pedig egy AVL 365C típusú szögjeladó mérte. A szívó és kipufogó oldali oxigénkoncentrációt egy Continental UniNox szenzorral mértük, mely a NO<sub>x</sub> koncentrációt is képes mérni.

### 1.2. A módszertan

A mérések során 1100 és 1600 rpm közt vettünk fel munkapontokat 50 rpm-es lépésközzel konstans 40%-os részterhelés mellett. Ezekben a munkapontokban 5 különböző EGR rátát vizsgáltunk meg, melyeket a HP-EGR segítségével állítottunk elő. Ezek rendre 0%, 15%, 30%, 40% és 55% voltak. Így összességében 55 minta áll rendelkezésre a neurális hálózat betanításához és értékeléséhez. Az EGR rátát a szívó és kipufogó oldali oxigénkoncentráció felhasználásával számoltuk ki az alábbi képlettel [12]:

$$EGR = \frac{O_{2\ in} - O_{2\ amb}}{O_{2\ out} - O_{2\ amb}} \cdot 100\%$$

A vizsgálat során az IMEP, a T<sub>max</sub>, a DoC, és az M meghatározásához 4 külön MLP hálózatot tanítottunk be, melyek 2 bemeneti paramétere a fordulatszám és az EGR ráta. A tanítás során a bemenetek és a kimenetek 0 és 1 közé lettek skálázva. A helyes háló architektúra megtalálásához grid-search eljárást alkalmaztunk. A korábbi tapasztalatainkra alapozva rétegenként 20 és 60 közti neuron számot vizsgáltunk meg 2 neuronos lépésközzel 1 és 2 réteg alkalmazása mellett. Az 55 mintából 35-öt használtunk fel a tanító adatsorhoz. Az összes lehetséges neuronszám kombinációt 10 validációs mintával megvizsgálva a legkisebb átlagos négyzetes eltérésűt (MSE) választottuk ki optimális architektúraként. A neurális hálózatokra jellemző véletlenszerűség kezelése céljából minden architektúra mellett 8-szor végeztük el a betanítást és az értékelést, és a végleges validációs MSE a 8 részeredmény átlaga lett. A tanító adatsor sorrendje minden ismételt tanítás előtt randomizálva lett, hogy a lokális minimumokat elkerüljük. Mivel a validációs adatsor alapján határozzuk meg a végleges architektúrát, ezért annak közvetett hatása van a végeredményre. A végleges hálózatot ezért 10 teszt mintával értékeltük, melyek eddig semmilyen formában nem vettek részt a háló előállításában.

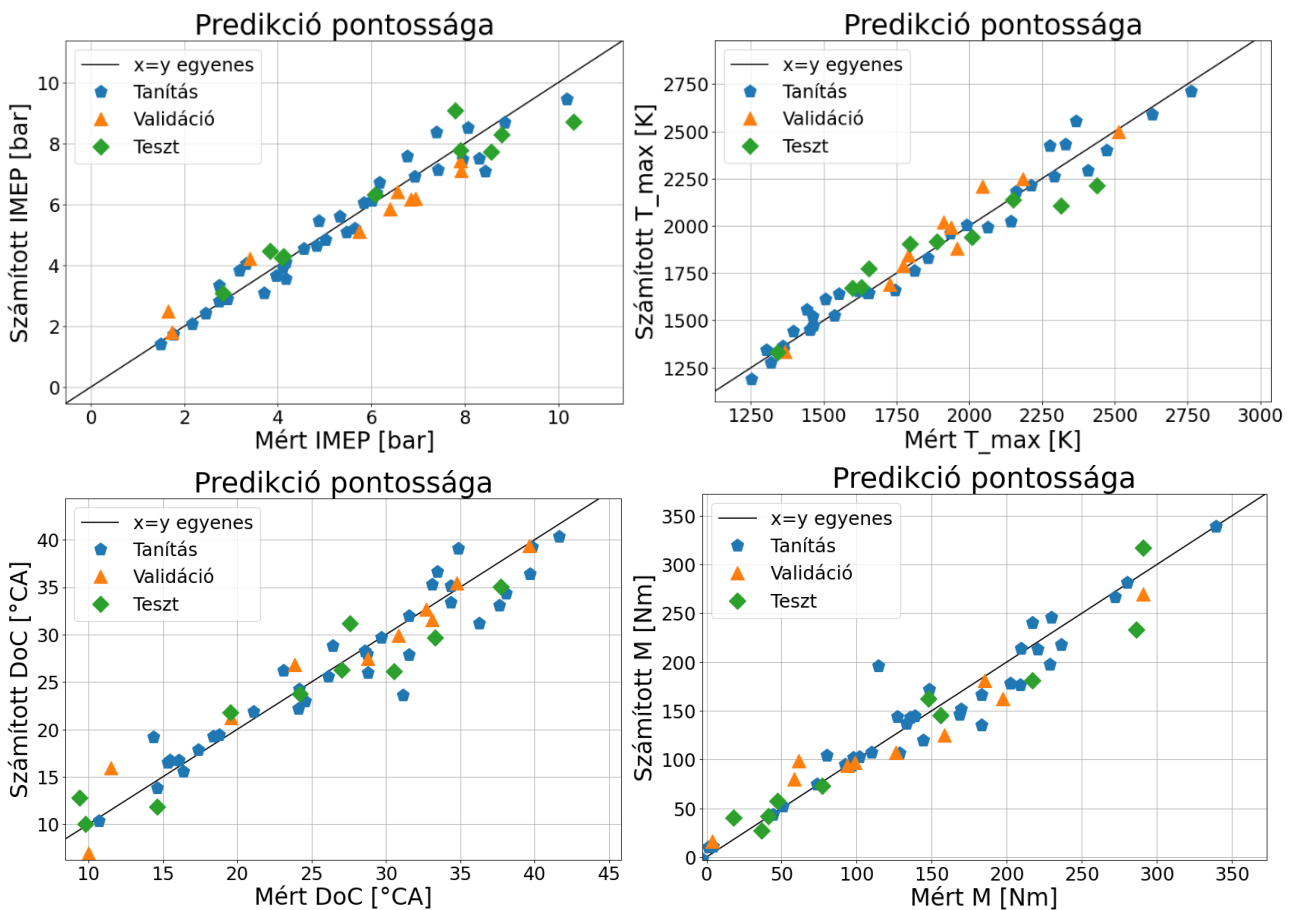
Az MLP hálózatok ReLU aktivációs függvénnyel rendelkeznek a rejtett rétegekben, és lineárisan a kimeneti rétegen. A súlyokat He-uniform módszerrel inicializáltuk, a tanítást pedig Adam algoritmussal végeztük 100 epoch méretű türelmi tényezővel és maximum 5000 epoch hosszúsággal.

## 3. AZ EREDMÉNYEK

A helyes architektúrák megállapítása után meghatároztuk a valós és a modellezett értékek közötti eltéréseket és más pontosságot leíró paramétereiket. Ezek a paraméterek az MSE, az átlagos négyzetes eltérés gyöke (RMSE), az átlagos százalékos eltérés (MAPE), a korrelációs együttható (R) és a determinációs együttható (R<sup>2</sup>) értékei a tanító, validációs és teszt adatsorra, valamint mind az 55 mintára. Az MSE-t a 0 és 1 közé skálázott adatsorra határoztuk meg, így a 4 kimenet eltérései összehasonlíthatók egymással. Az RMSE a skálázatlan adatsorra lett megállapítva, így az eredeti mértékegységekkel láthatók az eltérések. Ezek az értékek a 1-5. táblázatokban láthatóak.

Az R és az R<sup>2</sup> a modellek pontosságát jellemzik. Mivel mind a 4 kimeneti paraméter esetén 1-hez közeli ezek az értékek, ezért a hálózatok pontosan visszaadják a valós fizikai folyamatok jellegét. Általánosságban – bár nem minden esetben, megfigyelhető, hogy a tanító adatsorra a legpontosabb a modell, majd ezt a validációs és végül a teszt adatsor követi. Ez indokolja a teszt adatsor használatát az értékelés során, mert azokra a mintákra, amik részt vettek a végleges hálózat kialakításában, túl jó a modell – hiszen azok ezeken lettek optimalizálva. A 2. ábrán a predikció pontossága látható a 4 kimenetre. Az adatpontok egy-egy szélsőséges esettől eltekintve közel esnek az x=y egyeneshez, így ezen is látható, hogy a modellek jól közelítik a valóságot.

Az indikált középnyomás legjobb architektúrája a 2-28-22-1 lett. A korrelációs együttható magas, így az összefüggések jellegét pontosan követi a modell, viszont az RMSE értékeknél látható, hogy a teljes adatsorra 0,59 bar az átlagos eltérés. A 2. ábrán megfigyelhető, hogy a mért IMEP-ek átlaga 6 körüli, így az átlagos eltérés 10% körüli, amit a 3. táblázatban látható MAPE értékek is megerősítenek. Az égési csúcshőmérséklet predikciója a legjobb. Ezt 2-36-34-1 neuron struktúrával lehetett a legpontosabban modellezni, és a MAPE a teljes adatsorra 4% alatti. Az égéstartam esetén az optimális architektúra 2-44-48-1 lett. A vizsgált kimeneti paraméterek közül ezt lehetett a legpontosabban modellezni. Ha megnézzük a 0 és 1 közé skálázott adatsor MSE értékeit, láthatjuk, hogy ez majdnem duplája a többi paraméterének. A 2. ábrán is látható, hogy itt valamivel messzebb helyezkednek el a pontok az  $x=y$  egyenestől. Ettől függetlenül a  $3^{\circ}\text{CA}$  körüli RMSE nem annyira jelentős, a MAPE 10% körüli. A motornyomaték predikciója is pontos a 2-54-38-1 architektúra használatával. Ha megnézzük a MAPE értékeket, láthatjuk, hogy nagyon magasak. Ez azért van, mert vannak 0 Nm körüli mérési pontjaink is, így a MAPE képletében a nevezőbe ekkor nagyon kis szám kerül, ami nagyon magas százalékos eltérést eredményez ezekben az esetekben. Ilyenkor a MAPE nem használható az értékeléshez. Ehelyett az RMSE 25 Nm körüli értékét vizsgálhatjuk meg, ami a 200Nm körüli átlagos mért nyomatékhoz viszonyítva már akkora eltérést mutat, mint ami többi kimeneti paramétert is jellemzi.



2. ábra. A predikciók pontossága a 4 kimeneti paraméterre

Átlagos négyzetes eltérés 0 és 1 közé skálázott adatsor esetén

1. táblázat

|                  | MSE (skálázott adatsorra) |            |            |              |
|------------------|---------------------------|------------|------------|--------------|
|                  | Tanító                    | Validációs | Teszt      | Összes minta |
| IMEP             | 0,00328873                | 0,00509390 | 0,00911043 | 0,00461157   |
| T <sub>max</sub> | 0,00327557                | 0,00305369 | 0,00716994 | 0,00385795   |
| DoC              | 0,00730034                | 0,00757110 | 0,00983218 | 0,00793443   |
| M                | 0,00511039                | 0,00525554 | 0,00591942 | 0,00481728   |

Átlagos négyzetes eltérés gyöke

2. táblázat

|                  | RMSE     |            |            |              |
|------------------|----------|------------|------------|--------------|
|                  | Tanító   | Validációs | Teszt      | Összes minta |
| IMEP             | 0,49 bar | 0,61 bar   | 0,87 bar   | 0,59 bar     |
| T <sub>max</sub> | 84,23 K  | 83,2 K     | 127,62 K   | 93,55 K      |
| DoC              | 2,67 °CA | 2,6531 °CA | 3,0588 °CA | 2,7469 °CA   |
| M                | 22,53 Nm | 24,7 Nm    | 26,19 Nm   | 23,68 Nm     |

Átlagos százalékos eltérés

3. táblázat

|                  | MAPE   |            |        |              |
|------------------|--------|------------|--------|--------------|
|                  | Tanító | Validációs | Teszt  | Összes minta |
| IMEP             | 0,0783 | 0,1324     | 0,0985 | 0,0918       |
| T <sub>max</sub> | 0,0369 | 0,0371     | 0,0517 | 0,0396       |
| DoC              | 0,0848 | 0,1228     | 0,1391 | 0,1016       |
| M                | 0,5806 | 0,6751     | 0,2832 | 0,5437       |

Korrelációs együtthatók

4. táblázat

|                  | R      |            |        |              |
|------------------|--------|------------|--------|--------------|
|                  | Tanító | Validációs | Teszt  | Összes minta |
| IMEP             | 0,9745 | 0,9613     | 0,9409 | 0,9663       |
| T <sub>max</sub> | 0,9798 | 0,9566     | 0,9213 | 0,9702       |
| DoC              | 0,9499 | 0,9588     | 0,9436 | 0,9516       |
| M                | 0,9591 | 0,9494     | 0,9639 | 0,9593       |

Determinációs együtthatók

5. táblázat

|                  | R2     |            |        |              |
|------------------|--------|------------|--------|--------------|
|                  | Tanító | Validációs | Teszt  | Összes minta |
| IMEP             | 0,9497 | 0,9244     | 0,8853 | 0,9338       |
| T <sub>max</sub> | 0,9600 | 0,9151     | 0,8489 | 0,9414       |
| DoC              | 0,9024 | 0,9195     | 0,8905 | 0,9057       |
| M                | 0,9200 | 0,9015     | 0,9291 | 0,9202       |

## 4. KONKLÚZIÓ

A dolgozatban az MLP hálózatok predikciós képessége sikeresen bemutatásra került. A szakirodalmi tapasztalatokkal összhangban az indikált középnyomás, az égési csúcshőmérséklet, az égéstartam és a motornyomaték pontosan modellezhető a módszerrel. A korrelációs együtthatók az összes mintára nézve mind 1-hez közeli voltak, így a fizikai folyamatok valós jellegét sikerült jól közelíteni. Ezek az együtthatók az IMEP esetén 0,967; a  $T_{max}$  esetén 0,97; a Doc esetén 0,952; az M esetén pedig 0,959-re adódtak. Az eltérések vizsgálata szintén kielégítő eredményeket hozott, bár a néhány esetben megfigyelhető 10% körüli MAPE még javítható lenne. A javítást elsősorban egy jobb adatsorral lehetne elérni, ugyanis az 55 minta egy MLP hálózat tanításához és értékeléséhez kevés. A munka folytatásaként meg kell vizsgálni, hogy milyen felbontású motorfékpadi mérésekre van szükség a hálózatok pontos betanításához. Itt korlátozó tényezőként figyelembe kell venni a mérések költségességét is. Ezen kívül nem csak a változtatott paraméterek vehetők be a modell bemeneti paramétereire közé, hanem más belső állapotok is, melyeket mérünk. A releváns paramétereket korreláció analízis segítségével lehet azonosítani, és ezek használatával a modell tovább javítható. A saját és a szakirodalmi tapasztalatok alapján kijelenthető, hogy a mesterséges intelligencia alapú modellezés bizonyos területeken, például modell prediktív vezérlés esetén jó alternatívát nyújthat a hagyományos fizikai modellekkel szemben.

## KÖSZÖNETNYILVÁNÍTÁS

A projekt eredményei a KTI által biztosított KTI\_KVIG\_8-1\_2021 támogatással, az Innovatív Mobilitás Program finanszírozásában valósultak meg.

A kutatást az AVL Hungary Kft. támogatta.

## IRODALMI HIVATKOZÁSOK

- [1] T. Péter, I. Lakatos, F. Szauter and D. Pup, *Complex analysis of vehicle and environment dynamics*, 2016 12th IEEE/ASME MESA, 2016, pp. 1-7, doi: 10.1109/MESA.2016.7587112.
- [2] Zöldy M., Baranyi P. *Cognitive Mobility - CogMob*, 12th IEEE International Conference on Cognitive Infocommunications, Online on MaxWhere 3D Web, 2021.
- [3] Najafi G., Barat G., Talal F. Y., Hadi R. *Combustion Analysis of a CI Engine Performance Using Waste Cooking Biodiesel Fuel with an Artificial Neural Network Aid*, American Journal of Applied Sciences, Science Publications, 2007, 4 (10), 756-764.
- [4] Nikzadfar K., Shamekhi A. H. *Investigating the relative contribution of operational parameters on performance and emissions of a common-rail diesel engine using neural network*, Fuel, Elsevier, 125, 116-128, 2014.
- [5] Çay Y., Çiçek A., Kara F., Sagirolu S. *Prediction of engine performance for an alternative fuel using artificial neural network*, Applied Thermal Engineering, Elsevier, 2012, 37, 217-225.
- [6] Parlak A., Islamoglu Y., Yasar H., Egrisogut A. *Application of artificial neural network to predict specific fuel consumption and exhaust temperature for a Diesel engine*, Applied Thermal Engineering, Elsevier, 2006, 26, 824-828.
- [7] Kannan G. R., Balasubramanian K. R., Anand R. *Artificial Neural Network Approach to Study the Effect of Injection Pressure and Timing on Diesel Engine Performance Fueled with Biodiesel*, International Journal of Automotive Technology, 2013, 14(3), 507-519.
- [8] Gürgen S., Ünver B., Altın I. *Prediction of cyclic variability in a diesel engine fueled with n-butanol and diesel fuel blends using artificial neural network*, Renewable Energy, Elsevier, 2018, 117, 538-544.
- [9] Kerimcan Ç., Erinç U., Erdi T., Safak Y., Kadir A., Mustafa Ö. *Experimental and artificial neural network approach of noise and vibration characteristic of an unmodified diesel engine fuelled with conventional diesel, and biodiesel blends with natural gas addition*, Fuel, Elsevier, 2017, 197, 159-173.
- [10] S. Uslu, *Optimization of diesel engine operating parameters fueled with palm oildiesel blend: Comparative evaluation between response surface methodology (RSM) and artificial neural network (ANN)*, Fuel, Elsevier, 2020, 276, 117990.
- [11] Karonis D., Lois E., Zannikos F., Alexandridis A., Sarimveis H. *A Neural Network Approach for the Correlation of Exhaust Emissions from a Diesel Engine with Diesel Fuel Properties*, Energy & Fuels, ACS Publications, 2003, 17(5), 1259-1265.
- [12] Nyerges Á., Zöldy M. *Verification and Comparison of Nine Exhaust Gas Recirculation Mass Flow Rate Estimation Methods*, Sensors, MDPI, 2020, 20, 7291.